



**UNIVERSITATEA DIN PETROȘANI**  
**ȘCOALA DOCTORALĂ**

**Teză de doctorat**

Conducător de doctorat:

Prof.univ.habil.dr.ing. **Monica LEBA**

Student doctorand:

Ing. **Arun Fabian PANAITE**

Petroșani, 2024



**UNIVERSITATEA DIN PETROȘANI**  
**ȘCOALA DOCTORALĂ**

**Study regarding motion capture and  
identification**

Conducător de doctorat:

Prof.univ.habil.dr.ing. **Monica LEBA**

Student doctorand:

Ing. **Arun Fabian PANAITE**

Petroșani, 2024

## TABLE OF CONTENTS

Index of figures _____	4
Index of tables _____	8
Introduction _____	9

### CHAPTER 1

#### CURRENT TRENDS AND MOTION CAPTURE TECHNOLOGIES

<b>LITERATURE REVIEW _____</b>	<b>11</b>
1.1. Wearable motion capture devices and systems _____	13
1.2. Non-wearable sensor systems _____	14
1.3. Marker-based motion capture systems _____	18
1.4. Marker-less motion capture and simulation systems _____	20

### CHAPTER 2

#### FOUNDATIONS AND METHODOLOGIES FOR GAIT MOTION CAPTURE USING ACCELEROMETRIC SENSORS \_\_\_\_\_ 45

2.1. Experimental Design and Implementation of the Gait Motion Capture System _	45
2.2. Hardware Design of the Gait Motion Capture System _____	47
2.3. IMU Software Design for the Gait Motion Capture System _____	50
2.4. Simulation Model and MATLAB Simulink for Gait Motion Capture _____	53
2.5. Simulation Results _____	55
2.6. Conclusions _____	64

### CHAPTER 3

#### ADVANCED DATA MANIPULATION TECHNIQUES FOR OPTIMIZING IMAGE DATASETS IN NEURAL NETWORK TRAINING \_\_\_\_\_ 66

Overview _____	66
3.1. Frame Extraction _____	67
3.2. Color Temperature Adjustment _____	69
3.3. Background Blurring _____	73
3.4. Skeleton Drawing with Inverted Colors and Fringes _____	78

3.5. Initial Resizing and Detection _____	82
3.6. Final Resizing for Neural Network Training _____	86
3.7. Redundancy Removal _____	89
3.8. Conclusions _____	94
 <b>CHAPTER 4</b>	
<b>COMPARATIVE ANALYSIS OF CURSIVE POSE ESTIMATION MODELS</b> ____	<b>96</b>
4.1. ResNet-50 Training and Evaluation _____	97
4.1.1. Single CPU Training _____	98
4.1.2. Multiple CPU Training _____	105
4.1.3. Single GPU Training _____	111
4.1.4. Multiple GPU Training _____	115
4.2. GoogLeNet Training and Evaluation _____	121
4.2.1. Single CPU Training _____	122
4.2.2. Multiple CPU Training _____	125
4.2.3. Single GPU Training _____	128
4.2.4. Multiple GPU Training _____	131
4.3. GoogLeNet vs ResNet-50 Maximum Performance Comparison Description __	135
 <b>CHAPTER 5</b>	
<b>CONCLUSIONS AND HILIGHTS</b> _____	<b>137</b>
<b>CONTRIBUTIONS</b> _____	<b>143</b>
<b>FUTURE PERSPECTIVES AND ENHANCEMENTS</b> _____	<b>149</b>
<b>REFERENCES</b> _____	<b>150</b>
<b>ANNEXES</b> _____	<b>163</b>

## CAPITOLUL 1 – TENDINȚE ACTUALE ȘI TEHNOLOGII DE CAPTARE A MIȘCĂRII – REVIZUIREA LITERATURII

Lucrarea analizează realizările recente din domeniul tehnologiilor de captare a mișcării, concentrându-se pe evoluția sistemelor purtabile și a metodelor precise de monitorizare a mișcărilor umane. Dispozitivele purtabile de înregistrare a mișcării au devenit tot mai populare grație mobilității și facilității lor, demonstrând o precizie remarcabilă în detectarea gesturilor umane prin metode cum ar fi analiza trăsăturilor distinctive și reducerea dimensionalității. Aceste realizări au impact important în automatizarea industrială și în cercetările privind validarea utilizatorilor. Totuși, problemele legate de alimentarea cu energie și de design al senzorilor rămân nerezolvate, iar studiile viitoare se axează pe înglobarea acestor sisteme în robotică și optimizarea proiectării senzorilor pentru a maximiza interacțiunea în timp real și aplicațiile industriale.

Biomarkerii portabili sunt considerați un instrument promițător pentru urmărirea evoluției bolilor neurodegenerative. Algoritmii de machine learning pot procesa informațiile provenite din costumele de monitorizare a mișcării pentru a crea biomarkeri digitali, având potentialul de a diminua durata studiilor clinice în cazul afecțiunilor cu evoluție lentă. Totuși, se constată că există încă probleme în domeniul cercetării, mai ales legate de elaborarea unor metode de monitorizare mai exacte și investigarea aplicabilității biomarkerilor portabili în contextul studiilor clinice.

Capitolul include studii comparative care au confirmat fiabilitatea sistemelor de senzori purtabili în detectarea etapelor ciclului de mers, evidențiind capacitatea acestora pentru evaluări exacte ale modului de mers. Cu toate acestea, dificultățile referitoare la amplasarea strategică a senzorilor și constrângerile tehnologice rămân, iar studiile actuale se concentrează pe minimizarea numărului de senzori fără a afecta precizia.

În plus față de sistemele purtabile, teza examinează evoluțiile din domeniul senzorilor fixe. Au fost create abordări inovatoare pentru a perfecționa precizia captării mișcării, inclusiv sisteme automate ce folosesc date de adâncime și RGB provenite de la senzorii Kinect. Acestea au demonstrat capacitatea de a înregistra cu exactitate mișcările umane chiar cu ocluzii. De asemenea, s-a analizat tehnologia optică de detectare a mișcării în ceea ce privește potențialul său pentru programarea intuitivă a roboților și îmbunătățirea performanței acestora în aplicațiile industriale.

Integrarea sistemelor de învățare profundă în sistemele de captare a mișcării a condus la îmbunătățiri semnificative în estimarea mișcărilor umane. Aceste sisteme depășesc adesea abordările tradiționale folosind modele probabilistice care integrează raționamentul bazat pe datele și cunoștințele anterioare. Sistemele de captare a mișcării bazate pe markeri, validate ca alternative de cost redus la sistemele comerciale, s-au dovedit, de asemenea, eficiente în urmărirea mișcărilor corpului uman, cu algoritmi dezvoltați pentru a minimiza efectele artefactelor țesutului moale.

Sistemele de captare a mișcării fără markeri oferă mai multe avantaje față de sistemele tradiționale bazate pe markeri, utilizând algoritmi avansați și tehnici de învățare profundă pentru a estima pozițiile și orientările corpului. S-a demonstrat că aceste sisteme obțin un nivel ridicat

de acuratețe în captarea pozițiilor articulațiilor și a unghiurilor segmentelor, ceea ce le face potrivite pentru aplicații clinice și de cercetare.

În general, progresele în tehnologiile de captare a mișcării au îmbunătățit semnificativ acuratețea și eficiența analizei mișcărilor umane. Cu toate acestea, este nevoie de cercetări continue pentru a aborda provocările existente, a explora noi aplicații și a spori robustetea și ușurința de utilizare a acestor sisteme. Integrarea tehnologiilor de captare a mișcării cu învățarea automată și inteligența artificială oferă oportunități mari pentru viitor, deschizând noi posibilități pentru sisteme interactive în timp real, studii clinice și aplicații industriale.

## CAPITOLUL 2: FUNDAMENTE ȘI METODOLOGII PENTRU CAPTAREA MIȘCĂRII MERSULUI FOLOSIND SENSORI ACCELEROMETRICI

Capitolul 2, intitulat „Fundamente și metodologii pentru captarea mișcării mersului folosind senzori accelerometrici”, explorează proiectarea, implementarea și analiza unui sistem de captare a mișcării trunchiului inferior. Acest sistem, care utilizează senzori accelerometrici în combinație cu o placă Arduino, își propune să creeze o metodă simplă, portabilă și precisă pentru analiza mersului, cu aplicații în biomecanică, sănătate, știința sportului și reabilitare.

Capitolul începe prin detalierea proiectului experimental și a implementării sistemului, unde obiectivul principal a fost dezvoltarea unui sistem funcțional și precis de captare a mersului. Acest sistem integrează senzori accelerometrici pe 6 axe cu o placă Arduino pentru a înregistra date detaliate despre mers, concentrându-se pe parametri precum lungimea pasului, durata pasului și unghiurile articulațiilor. Componentele cheie utilizate includ placa Arduino Uno R3, un Extensor de port serial și MATLAB Simulink pentru procesarea și vizualizarea datelor în timp real. Sensorii au fost plasați strategic pe pelvis, coapse, gambe și picioare pentru a capta datele complete despre mișcarea membrelor inferioare. Participanții au mers într-un ritm natural într-un mediu controlat pentru a minimiza variațiile, cu mai multe încercări efectuate pentru a asigura fiabilitatea datelor.

Hardware-ul a fost asamblat având grijă ca senzorii să fie fixați în siguranță pe corp folosind curele ajustabile și conectați la placa Arduino prin Extensorul de port serial. Programarea plăcii Arduino a fost un pas important pentru inițializarea comunicării cu senzorii, citirea și preprocesarea datelor, precum și transmiterea acestora către MATLAB Simulink pentru procesare și vizualizare. Procesele de calibrare, atât statice cât și dinamice, au fost realizate pentru a asigura acuratețea senzorilor. Experimentul a confirmat acuratețea, fiabilitatea și ușurința de utilizare a sistemului, participanții raportând confort în utilizare.

Capitolul discută, de asemenea, proiectarea hardware, subliniind capacitatea senzorilor accelerometrici de a măsura atât accelerația liniară cât și viteza unghiulară. Sensorii au fost plasați strategic pe corp pentru a capta mișcările critice ale mersului, Extensorul de port serial jucând un rol cheie în gestionarea datelor provenite de la mai mulți senzori. Cablajul și conexiunile sigure au fost esențiale pentru menținerea integrității datelor, iar calibrarea regulată a asigurat acuratețea pe termen lung.

Proiectarea software-ului pentru Unitatea de Măsură Inerțială (IMU) este prezentată în detaliu, concentrându-se pe integrarea senzorilor, achiziția de date, procesarea și analiza în timp real. MATLAB Simulink a fost ales pentru capacitățile sale robuste de procesare a datelor în timp real, ușurința de utilizare și setul său extensiv de unelte, ceea ce îl face o alegere ideală pentru această cercetare. Proiectarea software-ului asigură achiziția precisă a datelor, reducerea zgomotului, calibrarea și vizualizarea datelor în timp real, îmbunătățind performanța generală a sistemului.

Capitolul se încheie cu o discuție despre proiectarea experimentală, subliniind integrarea tehnologiei moderne a senzorilor cu microcontrolerele, rentabilitatea sistemului, portabilitatea sa și potențialul acestuia de a fi utilizat în analiza mersului. Experimentul a demonstrat cu succes că tehnologia accesibilă poate fi utilizată pentru analiza mersului, cu dezvoltări viitoare care ar putea include învățarea automată pentru recunoașterea automată a modelelor de mers. În ansamblu, sistemul oferă un instrument valoros pentru cercetători, clinicieni și persoane interesate de analiza mersului, cu modularitatea și scalabilitatea sa, permițând îmbunătățiri viitoare.

### CAPITOLUL 3: TEHNICI AVANSATE DE PROCESARE A DATELOR PENTRU OPTIMIZAREA SETURILOR DE IMAGINI ÎN ANTRENAREA REȚELELOR NEURONALE

Capitolul 3 al documentului explorează în detaliu tehnici avansate de prelucrare a datelor, special concepute pentru optimizarea seturilor de imagini utilizate în antrenarea rețelelor neuronale. Capitolul acoperă întregul flux de lucru, de la extragerea cadrelor din fișiere video până la redimensionarea finală a imaginilor, asigurându-se că acestea sunt pregătite pentru a fi folosite în antrenarea rețelelor neuronale complexe, cum ar fi ResNet-50 și GoogLeNet.

Capitolul începe prin sublinierea necesității manipulării datelor în antrenarea rețelelor neuronale. Principalele motive includ asigurarea consistenței și standardizării seturilor de date, îmbunătățirea calității imaginilor, creșterea eficienței prin eliminarea datelor redundante și automatizarea proceselor pentru a economisi timp și a reduce erorile umane.

Primul pas în proces este extragerea cadrelor, unde cadre individuale sunt captate din fișiere video folosind scripturi Python care utilizează biblioteca OpenCV. Aceste cadre sunt salvate ca fișiere PNG, iar scriptul înregistrează progresul extragerii, asigurând un set complet de imagini care reprezintă diferite momente din video.

În continuare, capitolul discută ajustarea temperaturii de culoare, care este importantă pentru standardizarea imaginilor la o temperatură de 6500K, optimă pentru antrenarea CNN-urilor. Procesul implică calcularea temperaturii inițiale a fiecărei imagini, conversia valorilor Kelvin în RGB și aplicarea acestor valori pentru a ajusta balansul de culoare.

Estomparea fundalului este o altă tehnică discutată, care se concentrează pe evidențierea prim-planului (subiecți umani) prin estomparea fundalului. Acest proces folosește modelul de segmentare al Mediapipe pentru a crea măști pentru corpul uman și aplică Gaussian blur fundalului, menținând în același timp prim-planul clar, îmbunătățind astfel focalizarea pe caracteristicile relevante pentru antrenarea rețelelor neuronale.

Desenarea scheletului cu culori inverse și borduri este o metodă utilizată pentru a îmbunătăți caracteristicile vizuale ale corpului uman. Acest pas implică detectarea reperelor umane, inversarea culorilor în cadrul scheletului și adăugarea de borduri pentru a face caracteristicile mai ușor de distins pentru rețeaua neuronală. Această tehnică folosește estimarea poziției Mediapipe pentru a detecta reperi și adaugă borduri albe, negre și roșii scheletelor.

Capitolul include și redimensionarea imaginilor pe baza detectării obiectelor folosind YOLOv5, un model care identifică și decupează imaginile în jurul persoanelor detectate, concentrându-se pe conținutul relevant. Acest lucru asigură că părțile importante ale imaginilor sunt păstrate, reducând în același timp fundalul inutil, standardizând astfel setul de date pentru antrenarea rețelelor neuronale.

Redimensionarea finală este apoi realizată folosind biblioteca Pillow, care redimensionează imaginile la o dimensiune standard (de exemplu, 400x400 pixeli) necesară pentru antrenarea rețelelor neuronale. Acest pas asigură că setul de date este consistent în ceea ce privește dimensiunea de intrare, facilitând antrenarea și evaluarea eficientă a rețelelor neuronale.

Eliminarea redundanței este ultimul pas discutat, unde Indexul de Similaritate Structurală (SSIM) este folosit pentru a compara imaginile din același director și a elimina duplicatele pe baza unui prag de similaritate. Acest proces reduce dimensiunea setului de date prin eliminarea imaginilor redundante, asigurându-se că setul de date este divers și eficient.

Capitolul se încheie prin rezumarea întregului flux de lucru de manipulare a datelor, de la extragerea cadrelor până la redimensionarea finală, subliniind importanța fiecărui pas în pregătirea unui set de date robust pentru antrenarea rețelelor neuronale. De asemenea, evidențiază abordarea sistematică adoptată pentru a asigura că imaginile sunt de înaltă calitate, standardizate și pregătite pentru a fi utilizate în arhitecturi avansate de rețele neuronale.

## CHAPTER 4: ANALIZA COPARATIVĂ A MODELELOR DE ESTIMARE A POZIȚIEI

Capitolul 4 al documentului oferă o analiză comparativă detaliată a diferitelor modele de estimare a poziției, concentrându-se în special pe arhitecturile ResNet-50 și GoogLeNet. Obiectivul principal este evaluarea eficienței acestora în clasificarea pozițiilor ca "CORECT" sau "INCORECT" într-un sistem de clasificare binară a pozițiilor corpului uman. Capitolul include descrieri ale metodologiilor utilizate pentru antrenarea și evaluarea acestor modele, metricile utilizate pentru comparație și perspectivele obținute din analiză.

Modelele au fost antrenate folosind diferite configurații, inclusiv un singur CPU, mai multe CPU-uri, un singur GPU și multiple GPU-uri. Pentru fiecare configurație, procesul de antrenare a implicat monitorizarea acurateței, pierderii și timpului necesar. Metricile de evaluare au inclus acuratețea, precizia, reamintirea, scorul F1 și matricile de confuzie.

Pentru modelul ResNet-50, antrenarea pe un singur CPU a durat aproximativ 81 de minute, obținând o acuratețe ridicată a validării de 94,53% cu o supra-antrenare minimă. Antrenarea pe mai multe CPU-uri s-a extins la 86 de minute cu o acuratețe a validării de 92,58%. Antrenarea pe un singur GPU a redus semnificativ timpul la 11 minute, atingând o acuratețe a validării de 97,27%. Antrenarea pe multiple GPU-uri a durat aproximativ 14 minute, obținând o acuratețe a



validării de 96,88%. Rezultatele au arătat că antrenarea pe GPU, în special cu multiple GPU-uri, a oferit cea mai bună performanță atât în ceea ce privește viteza, cât și acuratețea.

Analiza pentru ResNet-50 a inclus vizualizări detaliate ale progresului antrenării, matrici de confuzie și metrici de performanță precum reamintirea, precizia și scorul F1. Antrenarea pe un singur CPU a arătat o creștere constantă a acurateței, stabilizându-se în jurul valorii de 94,53%, cu o pierdere scăzută și stabilă. Matricea de confuzie a evidențiat o precizie perfectă pentru clasa "CORECT" și o reamintire ridicată pentru clasa "INCORECT". Antrenarea pe mai multe CPU-uri a demonstrat tendințe similare, deși cu o acuratețe a validării ușor mai mică. Antrenarea pe un singur GPU a prezentat cea mai rapidă și mai eficientă învățare, cu cea mai mare acuratețe a validării și performanță consistentă pe metrici. Antrenarea pe multiple GPU-uri a oferit o acuratețe similară ridicată și un timp de antrenare eficient, indicând avantajele procesării paralele.

Pentru modelul GoogLeNet, antrenarea pe un singur CPU a durat aproximativ 94 de minute, obținând o acuratețe a validării de 92,97%. Antrenarea pe mai multe CPU-uri a arătat performanțe comparabile cu metrici de antrenare și validare stabile. Antrenarea pe un singur GPU a redus timpul la 13 minute, cu o acuratețe a validării de 93,36%. Antrenarea pe multiple GPU-uri a durat, de asemenea, aproximativ 14 minute, obținând o acuratețe a validării de 92,97%. Performanța modelului a fost robustă în diferite configurații, antrenarea bazată pe GPU oferind o eficiență semnificativă din punct de vedere al timpului.

Vizualizările pentru GoogLeNet au inclus grafice detaliate ale progresului antrenamentului, matrici de confuzie și metrici de performanță. Antrenarea pe un singur CPU a arătat o tendință constantă de creștere a acurateței, stabilizându-se în jurul valorii de 93-94%. Matricea de confuzie a relevat o precizie și o reamintire ridicată, în special pentru clasa "INCORECT". Antrenarea pe mai multe CPU-uri a menținut tendințe similare de acuratețe și pierdere, indicând o învățare eficientă. Antrenarea pe un singur GPU a demonstrat o învățare rapidă și o acuratețe ridicată a validării, în timp ce antrenarea pe multiple GPU-uri a oferit o antrenare eficientă cu o performanță robustă.

În concluzie, Capitolul 4 subliniază importanța resurselor computaționale în antrenarea modelelor de estimare a poziției. Antrenarea bazată pe GPU, în special cu multiple GPU-uri, îmbunătățește semnificativ eficiența antrenării și performanța modelului. Atât modelele ResNet-50, cât și GoogLeNet au arătat o acuratețe ridicată și robustețe în diferite configurații, făcându-le potrivite pentru sarcini de clasificare binară în estimarea poziției. Capitolul oferă perspective privind selectarea metodelor de antrenare adecvate pe baza resurselor disponibile și a cerințelor proiectului.

## CAPITOLUL 5: CONCLUZII, CONTRIBUȚII ȘI PUNCTE FORTE

Capitolul 5 oferă un set de concluzii legate de teză privind progresele și aplicațiile în tehnologiile de captare a mișcării, evidențiind progresul semnificativ realizat atât în sistemele portabile, cât și în cele non-portabile. Dispozitivele portabile de captare a mișcării, care sunt din ce în ce mai recunoscute pentru acuratețea lor ridicată în recunoașterea gesturilor umane, au un potențial vast în domenii care variază de la validarea utilizatorilor la automatizarea industrială. În ciuda provocărilor, cum ar fi limitările alimentării cu energie și deficiențele în designul senzorilor, se așteaptă ca cercetările continue să abordeze aceste probleme, în special în integrarea acestor

sisteme în robotică și în îmbunătățirea capacităților de lucru în timp real. Teza subliniază, de asemenea, potențialul biomarkerilor purtabili pentru monitorizarea bolilor neurodegenerative, ceea ce ar putea duce la monitorizarea mai precisă și la reducerea duratei studiilor clinice.

Sistemele de senzori non-purtabile au înregistrat, de asemenea, progrese considerabile, în special cu utilizarea datelor de adâncime și RGB de la senzorii Kinect și cu dezvoltarea cadrelor de învățare profundă pentru a estima mișcările brațului uman. Aceste inovații oferă o urmărire a mișcărilor mai precisă și mai cuprinzătoare, chiar și în scenarii complexe care implică ocluziuni. Integrarea unităților de măsurare inerțiale cu sistemele de captare a mișcării a îmbunătățit și mai mult acuratețea, făcând aceste sisteme valoroase în aplicații precum programarea roboților și evaluarea performanței industriale.

Această teză discută integrarea tehnologiilor de captare a mișcării cu inteligența artificială și învățarea automată, ceea ce a deschis noi căi pentru interpretarea mișcărilor umane complexe cu o acuratețe mai mare și în timp real. Această integrare este pe cale să revoluționeze diverse industrii, inclusiv sănătatea, sportul și divertismentul, oferind perspective mai profunde asupra biomecanicii umane și permițând intervenții mai personalizate.

În automatizarea industrială, tehnologiile de captare a mișcării sunt pregătite să îmbunătățească eficiența și siguranța prin permiterea roboților să înțeleagă și să reproducă mișcările umane, reducând timpul și expertiza necesare pentru procesele de automatizare. Aplicarea acestor tehnologii în realitatea virtuală (VR) și realitatea augmentată (AR) este, de asemenea, promițătoare, oferind experiențe mai imersive și interactive care sunt deosebit de relevante în jocuri, simulări de antrenament și colaborare la distanță.

În domeniul medical, tehnologiile de captare a mișcării oferă măsurători precise și obiective ale mișcării umane, care pot îmbunătăți diagnosticul și tratamentul tulburărilor musculo-scheletice și pot îmbunătăți procesele de reabilitare. Aceste tehnologii sunt, de asemenea, valoroase pentru urmărirea progresului bolilor și a eficacității intervențiilor, ceea ce ar putea reduce timpul și costurile studiilor clinice.

Teza se încheie subliniind importanța cercetării și dezvoltării continue în tehnologiile de captare a mișcării, deoarece aceste progrese au un potențial mare în diverse aplicații, de la automatizarea industrială la sănătate. Pe măsură ce tehnologiile senzorilor continuă să evolueze și să devină mai accesibile, se așteaptă ca adoptarea sistemelor de captare a mișcării să crească, conducând la noi inovații și aplicații în viitor.

## Îmbunătățiri viitoare

Dezvoltarea viitoare a acestei tehnologii este importantă pentru a depăși unele dintre provocările cu care se confruntă astăzi dezvoltarea senzorilor, inclusiv designul senzorilor, sursa de energie și sensibilitatea. Aceste provocări pot fi rezolvate prin crearea de senzori mai eficienți energetic și prin încorporarea mai multor senzori pentru a obține mai multe date fiziologice, extinzând utilizarea în domeniul sănătății, sportului și reabilitării fizice. Sistemele de captare a mișcării pot fi îmbunătățite prin extinderea utilizării învățării automate, în special prin utilizarea

algoritmilor RNN pentru clasificarea precisă a diferitelor modele de mișcare. Aceste modele ar putea fi reglate fin cu date noi și ar fi mai eficiente în diferite medii dacă sunt instruite continuu.

Aplicarea tehnologiilor de captare a mișcării în AR/VR oferă noi oportunități de interacțiune, în timp ce posibilitățile de îmbunătățire vizează dezvoltarea unor sisteme mai puțin invazive care ar crește confortul interacțiunii. Acest lucru s-ar putea extinde la domeniile de divertisment, formare și operare de la distanță a echipamentelor. Progresele viitoare din industria medicală pot integra captarea mișcării cu biosenzori purtabili pentru a îmbunătăți diagnosticul și evaluarea tratamentului, ceea ce poate scurta studiile și poate îmbunătăți tratamentul adaptat pacientului. Pentru a atinge aceste beneficii, este necesară standardizarea achiziției și procesării datelor, deoarece aplicarea unui cadru comun pentru preprocesarea, detectarea și analiza datelor de imagine este benefică pentru calitatea și omogenitatea datelor, care sunt esențiale pentru dezvoltarea și utilizarea modelului de învățare automată.

## REFERENCES

1. Abdel-Malek, K., & Arora, J. S. (2013). Human motion simulation: Predictive dynamics (1st ed.). Elsevier. <https://doi.org/10.1016/C2012-0-06906-8>
2. Abhayasinghe, N., Murray, I., & Sharif Bidabadi, S. (2019). Validation of thigh angle estimation using inertial measurement unit data against optical motion capture systems. *Sensors*, 19(3), 596. <https://doi.org/10.3390/s19030596>
3. Akhter, I., Simon, T., Khan, S., Matthews, I., & Sheikh, Y. (2012). Bilinear spatiotemporal basis models. *ACM Transactions on Graphics*, 31(2), Article 17. <https://doi.org/10.1145/2159516.2159523>
4. Alarcón-Aldana, A. C., Callejas-Cuervo, M., & Bo, A. P. L. (2020). Upper limb physical rehabilitation using serious videogames and motion capture systems: A systematic review. *Sensors*, 20(21), 5989. <https://doi.org/10.3390/s20215989>
5. Allen, B., Curless, B., & Popović, Z. (2003). The space of human body shapes: Reconstruction and parameterization from range scans. In *ACM SIGGRAPH 2003 Papers* (pp. 587-594). Association for Computing Machinery. <https://doi.org/10.1145/1201775.882311>
6. An, W. C., Ngali, M. Z., Kaharuddin, Z., & Khairu Razak, S. B. (2017). Performance of dual depth camera motion capture system for athletes' biomechanics analysis. *MATEC Web of Conferences*, 135, 00059. <https://doi.org/10.1051/mateconf/201713500059>
7. Arent, I., Schmidt, F. P., Botsch, M., & Dürr, V. (2021). Marker-less motion capture of insect locomotion with deep neural networks pre-trained on synthetic videos. *Frontiers in Behavioral Neuroscience*, 15, 637806. <https://doi.org/10.3389/fnbeh.2021.637806>
8. Arsenault, D., & Whitehead, A. (2015). Wearable sensor networks for motion capture. In *SG EAI*. <https://doi.org/10.4108/icst.intetain.2015.259265>
9. Arus, E., Ph.D. (2017). *Biomechanics of human motion: Applications in the martial arts* (2nd ed.). CRC Press. <https://doi.org/10.1201/b22446>

10. Banerjee, D., & Yu, K. (2019). Integrated test automation for evaluating a motion-based image capture system using a robotic arm. *IEEE Access*, 7, 1888-1896. <https://doi.org/10.1109/ACCESS.2018.2886272>
11. Beeler, T., Hahn, F., Bradley, D., Bickel, B., Beardsley, P., Gotsman, C., Sumner, R. W., & Gross, M. (2011). High-quality passive facial performance capture using anchor frames. *ACM Transactions on Graphics*, 30(4), 75. <https://doi.org/10.1145/2010324.1964970>
12. Bernardina, G. R. D., Cerveri, P., Barros, R. M. L., Marins, J. C. B., & Silvatti, A. P. (2016). Action sport cameras as an instrument to perform a 3D underwater motion analysis. *PLoS ONE*, 11(8), e0160490. <https://doi.org/10.1371/journal.pone.0160490>
13. Boddy, K. J., Marsh, J. A., Caravan, A., Lindley, K. E., Scheffey, J. O., & O'Connell, M. E. (2019). Exploring wearable sensors as an alternative to marker-based motion capture in the pitching delivery. *PeerJ*, 7, e6365. <https://doi.org/10.7717/peerj.6365>
14. Bosco, G., Delle Monache, S., Gravano, S., Indovina, I., La Scaleia, B., Maffei, V., Zago, M., & Lacquaniti, F. (2015). Filling gaps in visual motion for target capture. *Frontiers in Integrative Neuroscience*, 9, 13. <https://doi.org/10.3389/fnint.2015.00013>
15. Bravo, D. A., & Rengifo, C. F. R. (2015). Trajectory generation from motion capture for a planar biped robot in swing phase. *Ingeniería Y Ciencia*, 11(22), 25-47. <https://doi.org/10.17230/ingciencia.11.22.2>
16. Burger, B., & Toiviainen, P. (2013). MoCap Toolbox -- A Matlab toolbox for computational analysis of movement data. In R. Bresin (Ed.), *Proceedings of the 10th Sound and Music Computing Conference* (pp. 172-178). KTH Royal Institute of Technology.
17. Calderita, L. V., Bandera, J. P., Bustos, P., & Skiadopoulos, A. (2013). Model-based reinforcement of Kinect depth data for human motion capture applications. *Sensors*, 13(7), 8835-8855. <https://doi.org/10.3390/s130708835>
18. Canton-Ferrer, C., Casas, J. R., & Pardàs, M. (2010). Marker-based human motion capture in multiview sequences. *EURASIP Journal on Advances in Signal Processing*, 2010(1), 105476. <https://doi.org/10.1155/2010/105476>
19. Chanpimol, S., Seamon, B., Hernandez, H., Harris-Love, M., & Blackman, M. R. (2017). Using Xbox Kinect motion capture technology to improve clinical rehabilitation outcomes for balance and cardiovascular health in an individual with chronic TBI. *Archives of Physiotherapy*, 7(1). <https://doi.org/10.1186/s40945-017-0033-9>
20. Chatterton, G. J., Hansen, J. B., Kristiansen, N. H., Kunwald, N. P., Kersting, U. G., & Oliveira, A. S. (2022). Assessing kinematics and kinetics of high-speed running using inertial motion capture: A preliminary analysis. *ISBS Proceedings Archive*, 40(1), Article 29. Available at <https://commons.nmu.edu/isbs/vol40/iss1/29>
21. Chatzitofis, A., Zarpalas, D., Kollias, S., & Daras, P. (2019). DeepMoCap: Deep optical motion capture using multiple depth sensors and retro-reflectors. *Sensors*, 19(2), 282. <https://doi.org/10.3390/s19020282>
22. Chaumeil, A., Lahkar, B. K., Dumas, R., Muller, A., & Robert, T. (2022). Accuracy of a markerless motion capture system for balance related quantities. *bioRxiv*. <https://doi.org/10.1101/2022.11.10.515951>
23. Chen, H., Schall, M. C., & Fethke, N. B. (2020). Measuring upper arm elevation using an inertial measurement unit: An exploration of sensor fusion algorithms and gyroscope models. *Applied Ergonomics*, 89, 103187. <https://doi.org/10.1016/j.apergo.2020.103187>
24. Chen, P., Kuang, Y., & Li, J. (2016). Human motion capture algorithm based on inertial sensors. *Journal of Sensors*, 2016(1), 4343797. <https://doi.org/10.1155/2016/4343797>
25. Chen, S., Zhao, X., Luo, B., & Sun, Z. (2020). Visual browse and exploration in motion capture data with phylogenetic tree of context-aware poses. *Sensors*, 20(18), 5224. <https://doi.org/10.3390/s20185224>
26. Cheng, X., Gu, Y., Chen, B., Zhang, Y., & Shi, J. (2019). Weighted multiple instance-based deep correlation filter for video tracking processing. *IEEE Access*, 7, 161220-161230. <https://doi.org/10.1109/ACCESS.2019.2951600>

27. Chèze, L. (2014). Kinematic analysis of human movement. John Wiley & Sons, Inc. <https://doi.org/10.1002/9781119058144>
28. Cler, J. (2016). Commentary on "Measuring Aksak Rhythm and Synchronization in Transylvanian Village Music by Using Motion Capture". *Empirical Musicology Review*, 10(4), 302-304. <https://doi.org/10.18061/emr.v10i4.4960>
29. Climent-Pérez, P., & Florez-Revuelta, F. (2021). Improved action recognition with separable spatio-temporal attention using alternative skeletal and video pre-processing. *Sensors*, 21(3), 1005. <https://doi.org/10.3390/s21031005>
30. Clouthier, A. L., Ross, G. B., Mavor, M. P., Coll, I., Boyle, A., & Graham, R. B. (2021). Development and validation of a deep learning algorithm and open-source platform for the automatic labelling of motion capture markers. *IEEE Access*, 9, 36444-36454. <https://doi.org/10.1109/ACCESS.2021.3062748>
31. Cotton, S., Vanoncini, M., Fraisse, P., Ramdani, N., Demircan, E., Murray, A. P., & Keller, T. (2011). Estimation of the centre of mass from motion capture and force plate recordings: A study on the elderly. *Applied Bionics and Biomechanics*, 8(3-4), 123246. <https://doi.org/10.3233/ABB-2011-0006>
32. Cuadrado, J., Michaud, F., Lugiés, U., & Pérez Soto, M. (2021). Using accelerometer data to tune the parameters of an extended Kalman filter for optical motion capture: Preliminary application to gait analysis. *Sensors*, 21(2), 427. <https://doi.org/10.3390/s21020427>
33. Dahan, A., Noy, L., Hart, Y., Mayo, A., & Alon, U. (2016). Exit from synchrony in joint improvised motion. *PLoS ONE*, 11(10), e0160747. <https://doi.org/10.1371/journal.pone.0160747>
34. Das, K., de Paula Oliveira, T., & Newell, J. (2023). Comparison of markerless and marker-based motion capture systems using 95% functional limits of agreement in a linear mixed-effects modelling framework. *Scientific Reports*, 13, 22880. <https://doi.org/10.1038/s41598-023-49360-2>
35. De la Torre, J., Marin Bone, J., Ilarri, S., & Marin, J. (2020). Applying machine learning for healthcare: A case study on cervical pain assessment with motion capture. *Applied Sciences*, 10(17), 5942. <https://doi.org/10.3390/app10175942>
36. Delamare, M., Duval, F., & Bouteau, R. (2020). A new dataset of people flow in an industrial site with UWB and motion capture systems. *Sensors*, 20(16), 4511. <https://doi.org/10.3390/s20164511>
37. Dockstader, S. L., & Tekalp, A. M. (2002). A kinematic model for human motion and gait analysis. In *Proceedings*. Retrieved from <https://api.semanticscholar.org/CorpusID:18322318>
38. Dong, R., Cai, D., & Ikuno, S. (2020). Motion capture data analysis in the instantaneous frequency-domain using Hilbert-Huang transform. *Sensors*, 20(22), 6534. <https://doi.org/10.3390/s20226534>
39. Drapeaux, A., & Carlson, K. (2020). A comparison of inertial motion capture systems: DorsaVi and Xsens. *International Journal of Kinesiology and Sports Science*, 8(3), 24-27. <https://doi.org/10.7575/aiac.ijkss.v.8n.3p.24>
40. Dudzik, S. (2020). Application of the motion capture system to estimate the accuracy of a wheeled mobile robot localization. *Energies*, 13(23), 6437. <https://doi.org/10.3390/en13236437>
41. Dürsteler, M. R. (2014). A common framework for the analysis of complex motion? Standstill and capture illusions. *Frontiers in Human Neuroscience*, 8, 999. <https://doi.org/10.3389/fnhum.2014.00999>
42. Farella, E., Benini, L., Riccò, B., & Acquaviva, A. (2007). MOCA: A low-power, low-cost motion capture system based on integrated accelerometers. *Advances in Multimedia*, 2007(1), 082638. <https://doi.org/10.1155/2007/82638>
43. Fischer, G., Jermann, D., List, R., Reissner, L., & Calcagni, M. (2020). Development and application of a motion analysis protocol for the kinematic evaluation of basic and functional

- hand and finger movements using motion capture in a clinical setting—A repeatability study. *Applied Sciences*, 10(18), 6436. <https://doi.org/10.3390/app10186436>
44. Fleet, D. J. (2011). Motion models for people tracking. In T. B. Moeslund, A. Hilton, V. Krüger, & L. Sigal (Eds.), *Visual analysis of humans: Looking at people* (pp. 171-198). Springer London. [https://doi.org/10.1007/978-0-85729-997-0\\_10](https://doi.org/10.1007/978-0-85729-997-0_10)
  45. Fonk, R., Schneeweiss, S., Simon, U., & Engelhardt, L. (2021). Hand motion capture from a 3D Leap Motion controller for a musculoskeletal dynamic simulation. *Sensors*, 21(4), 1199. <https://doi.org/10.3390/s21041199>
  46. Freire, S., Santos, G., Armondes, A., Meneses, E. A. L., & Wanderley, M. M. (2020). Evaluation of inertial sensor data by a comparison with optical motion capture data of guitar strumming gestures. *Sensors*, 20(19), 5722. <https://doi.org/10.3390/s20195722>
  47. Fu, Q., Zhang, X., Xu, J., & Zhang, H. (2020). Capture of 3D human motion pose in virtual reality based on video recognition. *Complexity*, 2020(1), 8857748. <https://doi.org/10.1155/2020/8857748>
  48. Furtado, S., Galna, B., Godfrey, A., Rochester, L., & Gerrand, C. (2024). Feasibility of using low-cost markerless motion capture for assessing functional outcomes after lower extremity musculoskeletal cancer surgery. *PLoS ONE*, 19(3), e0300351. <https://doi.org/10.1371/journal.pone.0300351>
  49. Gamulescu, O. M., Rosca, S. D., Panaite, F., Costandoiu, A., & Riurean, S. (2020). Accident sites management using drones. *MATEC Web of Conferences*, 305, 00004. <https://doi.org/10.1051/matecconf/202030500004>
  50. Ganguly, A., Rashidi, G., & Mombaur, K. (2021). Comparison of the performance of the Leap Motion Controller™ with a standard marker-based motion capture system. *Sensors*, 21(5), 1750. <https://doi.org/10.3390/s21051750>
  51. Gao, Z., Yu, Y., Zhou, Y., & Du, S. (2015). Leveraging two Kinect sensors for accurate full-body motion capture. *Sensors*, 15(9), 24297-24317. <https://doi.org/10.3390/s150924297>
  52. García-Pinillos, F., Jaén-Carrillo, D., Soto Hermoso, V., Latorre Román, P., Delgado, P., Martínez, C., Carton, A., & Roche Seruendo, L. (2020). Agreement between spatiotemporal gait parameters measured by a markerless motion capture system and two reference systems—a treadmill-based photoelectric cell and high-speed video analyses: Comparative study. *JMIR Mhealth and Uhealth*, 8(10), e19498. <https://doi.org/10.2196/19498>
  53. Gasparutto, X., Wegrzyk, J., Rose-Dulcina, K., Hannouche, D., & Armand, S. (2020). Can the fusion of motion capture and 3D medical imaging reduce the extrinsic variability due to marker misplacements? *PLOS ONE*, 15(1), e0226648. <https://doi.org/10.1371/journal.pone.0226648>
  54. Giarmatzis, G., Zacharaki, E. I., & Moustakas, K. (2020). Real-time prediction of joint forces by motion capture and machine learning. *Sensors*, 20(23), 6933. <https://doi.org/10.3390/s20236933>
  55. Gleicher, M. (2002). Motion graphs. In *Proceedings of the 29th annual conference on Computer graphics and interactive techniques - SIGGRAPH '02* (10 pages).
  56. Grochow, K., Martin, S. L., Hertzmann, A., & Popović, Z. (2004). Style-based inverse kinematics. *ACM Transactions on Graphics (Proc. SIGGRAPH'04)*. Retrieved from <https://grail.cs.washington.edu/projects/styleik/styleik.pdf>
  57. Guo, H., & Sung, Y. (2020). Movement estimation using soft sensors based on Bi-LSTM and two-layer LSTM for human motion capture. *Sensors*, 20(6), 1801. <https://doi.org/10.3390/s20061801>
  58. Guo, L., & Xiong, S. (2017). Accuracy of base of support using an inertial sensor based motion capture system. *Sensors*, 17(9), 2091. <https://doi.org/10.3390/s17092091>
  59. Hafer, J. F., Mihy, J. A., Hunt, A., Zernicke, R. F., & Johnson, R. T. (2022). IMU-derived kinematics detect gait differences with age or knee osteoarthritis but differ from marker-derived inverse kinematics. *medRxiv*. <https://doi.org/10.1101/2022.01.10.22269024>

60. Halvorson, R. T., Castillo, F. T., Ahamed, F., Khattab, K., Scheffler, A., Matthew, R. P., et al. (2022). Point-of-care motion capture and biomechanical assessment improve clinical utility of dynamic balance testing for lower extremity osteoarthritis. *PLOS Digital Health*, 1(7), e0000068. <https://doi.org/10.1371/journal.pdig.0000068>
61. Hamill, J. (2010, July). Real-time measurement using EMG and motion capture systems. In *XXVIII International Symposium of Biomechanics in Sports* (pp. 78-81). Marquette, MI, USA. Url: <https://ojs.ub.uni-konstanz.de/cpa/article/view/4385>
62. Hamilton, L., Franklin, R. J. M., & Jeffery, N. D. (2007). Development of a universal measure of quadrupedal forelimb-hindlimb coordination using digital motion capture and computerised analysis. *BMC Neuroscience*, 8(1), 77. <https://doi.org/10.1186/1471-2202-8-77>
63. Harsted, S., Holsgaard-Larsen, A., Hestbæk, L., et al. (2019). Concurrent validity of lower extremity kinematics and jump characteristics captured in pre-school children by a markerless 3D motion capture system. *Chiropractic & Manual Therapies*, 27, 39. <https://doi.org/10.1186/s12998-019-0261-z>
64. Herda, L., Fua, P., Plankers, R., Boulic, R., & Thalmann, D. (2000). Skeleton-based motion capture for robust reconstruction of human motion. In *Proceedings of Computer Animation 2000* (pp. 77-83). <https://doi.org/10.1109/CA.2000.889046>
65. Hindle, B. R., Keogh, J. W. L., & Lorimer, A. V. (2021). Inertial-based human motion capture: A technical summary of current processing methodologies for spatiotemporal and kinematic measures. *Applied Bionics and Biomechanics*, 2021(1), 6628320. <https://doi.org/10.1155/2021/6628320>
66. Hodgins, J. K., Wooten, W. L., Brogan, D. C., & O'Brien, J. F. (1995). Animating human athletics. In *Proceedings of the 22nd Annual Conference on Computer Graphics and Interactive Techniques* (pp. 71-78). Association for Computing Machinery. <https://doi.org/10.1145/218380.218414>
67. Hu, H., Cao, Z., Yang, X., Xiong, H., & Lou, Y. (2021). Performance evaluation of optical motion capture sensors for assembly motion capturing. *IEEE Access*, 9, 61444-61454. <https://doi.org/10.1109/ACCESS.2021.3074260>
68. Hu, S., Dai, M., Dong, T., & Liu, T. (2019). A textile sensor for long durations of human motion capture. *Sensors*, 19(10), 2369. <https://doi.org/10.3390/s19102369>
69. Hwang, J., Ishii, S., Kwon, T., & Oba, S. (2020). Modularized predictive coding-based online motion synthesis combining environmental constraints and motion-capture data. *IEEE Access*, 8, 202274-202285. <https://doi.org/10.1109/ACCESS.2020.3036449>
70. Iliyasu, A. M. (2013). Towards realising secure and efficient image and video processing applications on quantum computers. *Entropy*, 15(8), 2874-2974. <https://doi.org/10.3390/e15082874>
71. Imanullah, M., Yuniarno, E. M., & Sooai, A. G. (2019). A novel approach in low-cost motion capture system using color descriptor and stereo webcam. *International Journal of Technology*, 10(5), 291-319. <https://doi.org/10.14716/ijtech.v10i5.2789>
72. Jackson, B. E., Evangelista, D. J., Ray, D. D., & Hedrick, T. L. (2016). 3D for the people: Multi-camera motion capture in the field with consumer-grade cameras and open source software. *Biology Open*, 5(9), 1334-1342. <https://doi.org/10.1242/bio.018713>
73. Jaume-i-Capó, A., Varona, J., González-Hidalgo, M., & Perales, F. J. (2009). Adding image constraints to inverse kinematics for human motion capture. *EURASIP Journal on Advances in Signal Processing*, 2010, 142354. <https://doi.org/10.1155/2010/142354>
74. Jensen, G. W., van der Smagt, P., Heiss, E., Straka, H., & Kohl, T. (2020). SnakeStrike: A low-cost open-source high-speed multi-camera motion capture system. *Frontiers in Behavioral Neuroscience*, 14, 116. <https://doi.org/10.3389/fnbeh.2020.00116>
75. Jiao, C., Yang, J., Wang, X., & Liang, B. (2019). Adaptive coordinated motion control with variable forgetting factor for a dual-arm space robot in post-capture of a noncooperative target. *International Journal of Advanced Robotic Systems*, 16(5). <https://doi.org/10.1177/1729881419872342>

76. Johnson-Glenberg, M. C., & Megowan-Romanowicz, C. (2017). Embodied science and mixed reality: How gesture and motion capture affect physics education. *Cognitive Research: Principles and Implications*, 2(1), 24. <https://doi.org/10.1186/s41235-017-0060-9>
77. Kadirvelu, B., Gavriel, C., Nageswaran, S., et al. (2023). A wearable motion capture suit and machine learning predict disease progression in Friedreich's ataxia. *Nature Medicine*, 29(1), 86-94. <https://doi.org/10.1038/s41591-022-02159-6>
78. Kanade, T., & Narayanan, P. J. (2007). Virtualized reality: Perspectives on 4D digitization of dynamic events. *IEEE Computer Graphics and Applications*, 27(3), 32-40. <https://doi.org/10.1109/MCG.2007.72>
79. Kang, J., Badi, B., Zhao, Y., & Wright, D. K. (n.d.). Human motion modeling and simulation by anatomical approach. Brunel University. Retrieved from [http://ndl.ethernet.edu.et/bitstream/123456789/88742/1/2017\\_Book\\_FundamentalsOfBiomechanics.pdf](http://ndl.ethernet.edu.et/bitstream/123456789/88742/1/2017_Book_FundamentalsOfBiomechanics.pdf)
80. Kanko, R. M., Laende, E. K., Davis, E. M., Selbie, W. S., & Deluzio, K. J. (2021). Concurrent assessment of gait kinematics using marker-based and markerless motion capture. *Journal of Biomechanics*, 127, 110665. <https://doi.org/10.1016/j.jbiomech.2021.110665>
81. Karatsidis, A., Bellusci, G., Schepers, H. M., De Zee, M., Andersen, M. S., & Veltink, P. H. (2017). Estimation of ground reaction forces and moments during gait using only inertial motion capture. *Sensors*, 17(1), 75. <https://doi.org/10.3390/s17010075>
82. Keizer, M. N. J., & Otten, E. (2020). Technical note: Sensitivity analysis of the SCoRE and SARA methods for determining rotational axes during tibiofemoral movements using optical motion capture. *Journal of Experimental Orthopaedics*, 7, 6. <https://doi.org/10.1186/s40634-020-0219-z>
83. Kessler, S. E., Rainbow, M. J., Lichtwark, G. A., Cresswell, A. G., D'Andrea, S. E., Konow, N., & Kelly, L. A. (2019). A direct comparison of biplanar videoradiography and optical motion capture for foot and ankle kinematics. *Frontiers in Bioengineering and Biotechnology*, 7, 199. <https://doi.org/10.3389/fbioe.2019.00199>
84. Kim, Y. (2017). Dance motion capture and composition using multiple RGB and depth sensors. *International Journal of Distributed Sensor Networks*, 13(2). <https://doi.org/10.1177/1550147717696083>
85. Kim, S., & Nussbaum, M. A. (2014). Evaluation of two approaches for aligning data obtained from a motion capture system and an in-shoe pressure measurement system. *Sensors*, 14(9), 16994-17007. <https://doi.org/10.3390/s140916994>
86. Kim, B.-G. (2020). Digital signal, image and video processing for emerging multimedia technology. *Electronics*, 9(12), 2012. <https://doi.org/10.3390/electronics9122012>
87. Kita, Y., Gunji, A., Sakuma, R., Goto, T., Okumura, Y., & Inagaki, M. (2017). Training attention to the other's need improves helping behaviors in children with autism spectrum disorder: A behavioral analysis using a two-dimensional motion capture system. *Frontiers in Education*, 2. <https://doi.org/10.3389/educ.2017.00050>
88. Kitzig, A., Demmer, J., Bolten, T., Naroska, E., Stockmanns, G., Viga, R., & Grabmaier, A. (2018). An HMM-based averaging approach for creating mean motion data from a full-body motion capture system to support the development of a biomechanical model. *Current Directions in Biomedical Engineering*, 4(1), 389-393. <https://doi.org/10.1515/cdbme-2018-0093>
89. Knight, J. (2008). Rotation points from motion capture data using a closed form solution. In *Proceedings*. <https://api.semanticscholar.org/CorpusID:61197979>
90. Knippenberg, E., Verbrugghe, J., Lamers, I., Palmaers, S., Timmermans, A., & Spooren, A. (2017). Markerless motion capture systems as training device in neurological rehabilitation: A systematic review of their use, application, target population and efficacy. *Journal of NeuroEngineering and Rehabilitation*, 14(1), 61. <https://doi.org/10.1186/s12984-017-0270-x>
91. Knyaz, V. A. (2015). SCALABLE PHOTOGRAMMETRIC MOTION CAPTURE SYSTEM "MOSCA": Development and application. *The International Archives of the Photogrammetry*,



- Remote Sensing and Spatial Information Sciences, XL-5/W6, 43-49.  
<https://doi.org/10.5194/isprsarchives-XL-5-W6-43-2015>
92. Kokubu, T., Mifune, Y., Inui, A., Kuroda, R., & Kurosaka, M. (2016). Clinical outcome of arthroscopic fixation for glenoid fracture using a double threaded screw. *Asia-Pacific Journal of Sports Medicine, Arthroscopy, Rehabilitation and Technology*, 6, 34.  
<https://doi.org/10.1016/j.asmart.2016.07.079>
  93. Kopf, M., Schulder, M., & Hanke, T. (2022). The Sign Language Dataset Compendium: Creating an overview of digital linguistic resources. In E. Efthimiou, S.-E. Fotinea, T. Hanke, J. A. Hochgesang, J. Kristoffersen, J. Mesch, & M. Schulder (Eds.), *Proceedings of the LREC2022 10th Workshop on the Representation and Processing of Sign Languages: Multilingual Sign Language Resources* (pp. 102-109). European Language Resources Association (ELRA). <https://www.sign-lang.uni-hamburg.de/lrec/pub/22025.pdf>
  94. Kruglov, A., Chiryshv, A., & Shishko, E. (2016). Applying of the NVIDIA CUDA to the video processing in the task of the roundwood volume estimation. *ITM Web of Conferences*, 8, 01009. <https://doi.org/10.1051/itmconf/20160801009>
  95. Kumar, K., Varghese, A., Reddy, P., Narendra, N., Swamy, P., Chandra, M., & Purushothaman, B. (2014). An improved tracking using IMU and vision fusion for mobile augmented reality applications. *The International Journal of Multimedia & Its Applications*, 6. <https://doi.org/10.5121/ijma.2014.6502>
  96. Kurniati, N., Basuki, A., & Pramadihanto, D. (2016). Remo dance motion estimation with markerless motion capture using the optical flow method. *EMITTER International Journal of Engineering Technology*, 3(1), 1-18. <https://doi.org/10.24003/emitter.v3i1.33>
  97. Kwon, T., & Hodgins, J. (2010). Control systems for human running using an inverted pendulum model and a reference motion capture sequence. In Z. Popovic & M. Otaduy (Eds.), *Eurographics/ACM SIGGRAPH Symposium on Computer Animation* (pp. 129-138). The Eurographics Association. <https://doi.org/10.2312/SCA/SCA10/129-138>
  98. Lee, J. K., & Jung, W. C. (2018). Quaternion-based local frame alignment between an inertial measurement unit and a motion capture system. *Sensors*, 18(11), 4003.  
<https://doi.org/10.3390/s18114003>
  99. Lewis, J. P., Corder, M., & Fong, N. (2023). Pose space deformation: A unified approach to shape interpolation and skeleton-driven deformation (Doctoral dissertation). Association for Computing Machinery. <https://doi.org/10.1145/3596711.3596796>
  100. Li, W., Zeng, Y., Zhang, Q., Wu, Y., & Chen, G. (2021). Human motion capture based on incremental dimension reduction and projection position optimization. *Wireless Communications and Mobile Computing*, 2021, 5589100.  
<https://doi.org/10.1155/2021/5589100>
  101. Li, M., Zhou, Z., & Liu, X. (2020). 3D hypothesis clustering for cross-view matching in multi-person motion capture. *Computational Visual Media*, 6, 147-156.  
<https://doi.org/10.1007/s41095-020-0171-y>
  102. Li, J., Zhang, J., Wang, Z., Shen, S., Wen, C., Ma, Y., Xu, L., Yu, J., & Wang, C. (2022). LiDARCap: Long-range markerless 3D human motion capture with LiDAR point clouds. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 20470-20480). <https://doi.org/10.1109/CVPR52688.2022.01985>
  103. Li, C. (2020). Badminton motion capture with visual image detection of picking robotics. *International Journal of Advanced Robotic Systems*, 17(6).  
<https://doi.org/10.1177/1729881420969072>
  104. Li, S., Cui, L., Zhu, C., Li, B., Zhao, N., & Zhu, T. (2016). Emotion recognition using Kinect motion capture data of human gaits. *PeerJ*, 4, e2364. <https://doi.org/10.7717/peerj.2364>
  105. Li, J., Xiao, D., Li, K., & Li, J. (2021). Graph matching for marker labeling and missing marker reconstruction with bone constraint by LSTM in optical motion capture. *IEEE Access*, 9, 34868-34881. <https://doi.org/10.1109/ACCESS.2021.3060385>

106. Ligorio, G., & Sabatini, A. M. (2016). Dealing with magnetic disturbances in human motion capture: A survey of techniques. *Micromachines*, 7(3), 43. <https://doi.org/10.3390/mi7030043>
107. Long, J., & Jones, M. D. (2013). Reconstructing 3D tree models using motion capture and particle flow. *International Journal of Computer Games Technology*, 2013(1), 363160. <https://doi.org/10.1155/2013/363160>
108. Ma, H., Yan, W., Yang, Z., & Liu, H. (2019). Real-time foot-ground contact detection for inertial motion capture based on an adaptive weighted naive Bayes model. *IEEE Access*, 7, 130312-130326. <https://doi.org/10.1109/ACCESS.2019.2939839>
109. Maidhof, C., Pitkaniemi, A., & Tervaniemi, M. (2013). Predictive error detection in pianists: A combined ERP and motion capture study. *Frontiers in Human Neuroscience*, 7, 587. <https://doi.org/10.3389/fnhum.2013.00587>
110. Marin, J., Blanco, T., & Marin, J. J. (2017). Octopus: A design methodology for motion capture wearables. *Sensors*, 17(8), 1875. <https://doi.org/10.3390/s17081875>
111. Markova, K., Dovramadjiev, T., & Jecheva, G. (2017, December 28). Computer parametric designing in Blender software for creating 3D paper models. *Annual Journal of Technical University of Varna, Bulgaria*, 1(1), 77-84. <https://doi.org/10.29114/ajtuv.vol1.iss1.44>
112. Martinez, H. R., Garcia-Sarreon, A., Camara-Lemarro, C., Salazar, F., & Guerrero-González, M. L. (2018). Accuracy of markerless 3D motion capture evaluation to differentiate between On/Off status in Parkinson's disease after deep brain stimulation. *Parkinson's Disease*, 2018, 5830364. <https://doi.org/10.1155/2018/5830364>
113. Masiero, A., Fissore, F., Antonello, R., Cenedese, A., & Vettore, A. (2019). A comparison of UWB and motion capture UAV indoor positioning. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W13, 1695-1699. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-1695-2019>
114. Maulana, G. G., Erdani, Y., Budiarto, A., & Purnomo, W. (2018). Design and building motion capture system using transducer Microsoft Kinect to control robot humanoid. *MATEC Web of Conferences*, 197, 11007. <https://doi.org/10.1051/mateconf/201819711007>
115. Mazzarella, J., McNally, M., Richie, D., Chaudhari, A. M. W., Buford, J. A., Pan, X., & Heathcock, J. C. (2020). 3D motion capture may detect spatiotemporal changes in pre-reaching upper extremity movements with and without a real-time constraint condition in infants with perinatal stroke and cerebral palsy: A longitudinal case series. *Sensors*, 20(24), 7312. <https://doi.org/10.3390/s20247312>
116. Menolotto, M., Komaris, D.-S., Tedesco, S., O'Flynn, B., & Walsh, M. (2020). Motion capture technology in industrial applications: A systematic review. *Sensors*, 20(19), 5687. <https://doi.org/10.3390/s20195687>
117. Merino, E., Mannrich, G., Guimarães, B., Speck, G., Matos, D., Domenech, S., & Merino, G. (2018). Implementation of integrated instrumentation in assistive technology. In F. Rebelo & M. Soares (Eds.), *Advances in Ergonomics in Design* (pp. 549-560). Springer International Publishing. [https://doi.org/10.1007/978-3-319-60582-1\\_55](https://doi.org/10.1007/978-3-319-60582-1_55)
118. Mihálik, A., Ďurikovič, R., & Sejš, M. (2018). Application of motion capture attributes to individual identification under corridor surveillance. *Journal of Applied Mathematics, Statistics and Informatics*, 14(1), 37-56. <https://doi.org/10.2478/jamsi-2018-0004>
119. Min, X., Sun, S., Wang, H., Zhang, X., Li, C., & Zhang, X. (2019). Motion capture research: 3D human pose recovery based on RGB video sequences. *Applied Sciences*, 9(17), 3613. <https://doi.org/10.3390/app9173613>
120. Moradzadeh, A., Mansour-Saatloo, A., Mohammadi-Ivatloo, B., & Anvari-Moghaddam, A. (2020). Performance evaluation of two machine learning techniques in heating and cooling loads forecasting of residential buildings. *Applied Sciences*, 10(11), 3829. <https://doi.org/10.3390/app10113829>
121. Mündermann, L., Corazza, S., & Andriacchi, T. P. (2006). The evolution of methods for the capture of human movement leading to markerless motion capture for biomechanical

- applications. *Journal of NeuroEngineering and Rehabilitation*, 3(1), 6.  
<https://doi.org/10.1186/1743-0003-3-6>
122. Naeemabadi, M., Dinesen, B., Andersen, O. K., & Hansen, J. (2018). Investigating the impact of a motion capture system on Microsoft Kinect v2 recordings: A caution for using the technologies together. *PLOS ONE*, 13(9), 1-17. <https://doi.org/10.1371/journal.pone.0204052>
  123. Nakamura, T., Koga, H., Horie, M., Watanabe, T., Yagishita, K., Sekiya, I., & Muneta, T. (2016). Postoperative outcome is affected by an intraoperative combination of each graft tension change pattern in a double-bundle anterior cruciate ligament reconstruction. *Asia-Pacific Journal of Sports Medicine, Arthroscopy, Rehabilitation and Technology*, 6, 1-6. <https://doi.org/10.1016/j.asmart.2016.08.002>
  124. Nakamura, T., Matsumoto, J., Nishimaru, H., Bretas, R. V., Takamura, Y., Hori, E., ... & Ono, T. (2016). A markerless 3D computerized motion capture system incorporating a skeleton model for monkeys. *PLoS ONE*, 11(11), e0166154. <https://doi.org/10.1371/journal.pone.0166154>
  125. Nakano, N., Sakura, T., Ueda, K., Omura, L., Kimura, A., Iino, Y., Fukashiro, S., & Yoshioka, S. (2020). Evaluation of 3D markerless motion capture accuracy using OpenPose with multiple video cameras. *Frontiers in Sports and Active Living*, 2, 50. <https://doi.org/10.3389/fspor.2020.00050>
  126. National Health and Nutrition Examination Survey (U.S.), National Center for Health Statistics (U.S.), & Westat. (1988, October). National Health and Nutrition Examination Survey III: Body measurements (anthropometry). <https://stacks.cdc.gov/view/cdc/53134>
  127. Nicolella, D. P., Torres-Ronda, L., Saylor, K. J., & Schelling, X. (2018). Validity and reliability of an accelerometer-based player tracking device. *PLoS ONE*, 13(2), e0191823. <https://doi.org/10.1371/journal.pone.0191823>
  128. Niu, J., Wang, X., Wang, D., & Ran, L. (2020). A novel method of human joint prediction in an occlusion scene by using low-cost motion capture technique. *Sensors*, 20(4), 1119. <https://doi.org/10.3390/s20041119>
  129. O'Brien, J. F., Bodenheimer, R. E., Brostow, G. J., & Hodgins, J. K. (2000, May). Automatic joint parameter estimation from magnetic motion capture data. In *Proceedings of Graphics Interface 2000* (pp. 53-60). Retrieved from <http://graphics.cs.berkeley.edu/papers/Obrien-AJP-2000-05/>
  130. Olar, M. L., Risteiu, M., Panaite, A. F., Rebrisoreanu, M., & Musetoiu, O. (2020). Controlling a robotic arm with augmented reality. *MATEC Web of Conferences*, 305, 00022. <https://doi.org/10.1051/mateconf/202030500022>
  131. Olar, M. L., Panaite, A. F., Leba, M., & Sibişanu, R. (2021). Stewart platform modified into a bio-inspirational device of the human shoulder. In Á. Rocha, H. Adeli, G. Dzemyda, F. Moreira, & A. M. Ramalho Correia (Eds.), *Trends and Applications in Information Systems and Technologies* (pp. 151-160). Springer International Publishing. [https://doi.org/10.1007/978-3-030-72654-6\\_15](https://doi.org/10.1007/978-3-030-72654-6_15)
  132. Ossendorff, R., Richter, J., Heijens, E., Schildberg, F., Haeder, G., & Salzmann, G. (2023). The validity of motion capture analysis system against the gold standard long-standing radiography in the measurement of lower extremity alignment. *Journal of Clinical Medicine*, 12(2), 567. <https://doi.org/10.3390/jcm12020567>
  133. Ostrek, M., Rhodin, H., Fua, P., Müller, E., & Spörri, J. (2019). Are existing monocular computer vision-based 3D motion capture approaches ready for deployment? A methodological study on the example of alpine skiing. *Sensors*, 19(19), 4323. <https://doi.org/10.3390/s19194323>
  134. Özkaya, N., Leger, D., Goldsheyder, D., & Nordin, M. (2017). *Fundamentals of biomechanics: Equilibrium, motion, and deformation* (4th ed.). Springer International Publishing. <https://doi.org/10.1007/978-3-319-44738-4>

135. Panaite, A. F., Leba, M., Olar, M. L., Sibisanu, R. C., & Pellegrini, L. (2021). Human arm motion capture using gyroscopic sensors. *MATEC Web of Conferences*, 343, 08007. <https://doi.org/10.1051/mateconf/202134308007>
136. Panaite, A. F., Rosca, S., & Sibişanu, R. (2021). Pose and motion capture technologies. *MATEC Web of Conferences*, 342, 05004. <https://doi.org/10.1051/mateconf/202134205004>
137. Panaite, A., Rîsteiu, M.-N., Olar, M., Leba, M., & Ionica, A. (2019). Hand rehabilitation - a gaming experience. *IOP Conference Series: Materials Science and Engineering*, 572, 012092. <https://doi.org/10.1088/1757-899X/572/1/012092>
138. Panaite, A. F., & Bogdanffy, L. (2019). Reimagining vision with infinity mirrors. *MATEC Web of Conferences*, 290, 01011. <https://doi.org/10.1051/mateconf/201929001011>
139. Park, H. S., Kim, J. Y., Kim, J. G., Choi, S. W., & Kim, Y. (2013). A new position measurement system using a motion-capture camera for wind tunnel tests. *Sensors*, 13(9), 12329-12344. <https://doi.org/10.3390/s130912329>
140. Petrosyan, T., Dunoyan, A., & Mkrtchyan, H. (2020). Application of motion capture systems in ergonomic analysis. *Armenian Journal of Special Education*, 4(2), 107-117. <https://doi.org/10.24234/se.2020.1.1.157>
141. Prameswari, S. J., Basori, & Wihidayat, E. S. (2019). The comparison between the use of Blender and 3DS Max application toward students' comprehension of 3D animation subject at vocational school in Surakarta. *Indonesian Journal of Informatics Education*, 3(2). <https://doi.org/10.20961/ijie.v3i2.25200>
142. Protopapadakis, E., Voulodimos, A., Doulamis, A., Camarinopoulos, S., Doulamis, N., & Miaoulis, G. (2018). Dance pose identification from motion capture data: A comparison of classifiers. *Technologies*, 6(1), 31. <https://doi.org/10.3390/technologies6010031>
143. Rallis, I., Protopapadakis, E., Voulodimos, A., Doulamis, N., Doulamis, A., & Bardis, G. (2019). Choreographic pattern analysis from heterogeneous motion capture systems using dynamic time warping. *Technologies*, 7(3), 56. <https://doi.org/10.3390/technologies7030056>
144. Rambely, A. S., & Fazrolrozi. (2012). A six-link kinematic chain model of human body using Kane's method. *International Journal of Modern Physics: Conference Series*, 9, 59-67. <https://doi.org/10.1142/S2010194512005107>
145. Reis, P. M. R., & Lochmann, M. (2015). Using a motion capture system for spatial localization of EEG electrodes. *Frontiers in Neuroscience*, 9, 130. <https://doi.org/10.3389/fnins.2015.00130>
146. Ren, T., Li, W., Jiang, Z., Li, X., Huang, Y., & Peng, J. (2020). Video-based human motion capture data retrieval via MotionSet Network. *IEEE Access*, 8, 186212-186221. <https://doi.org/10.1109/ACCESS.2020.3030258>
147. Reuter, A. S., & Schindler, M. (2023). Motion capture systems and their use in educational research: Insights from a systematic literature review. *Education Sciences*, 13(2), 167. <https://doi.org/10.3390/educsci13020167>
148. Riazati, S., McGuirk, T. E., Perry, E. S., Sihanath, W. B., & Patten, C. (2022). Absolute reliability of gait parameters acquired with markerless motion capture in living domains. *Frontiers in Human Neuroscience*, 16. <https://doi.org/10.3389/fnhum.2022.867474>
149. Ricci, L., Formica, D., Sparaci, L., Lasorsa, F. R., Taffoni, F., Tamilia, E., & Guglielmelli, E. (2014). A new calibration methodology for thorax and upper limbs motion capture in children using magneto and inertial sensors. *Sensors*, 14(1), 1057-1072. <https://doi.org/10.3390/s140101057>
150. Richter, C., Daniels, K. A. J., King, E., & Franklyn-Miller, A. (2020). Agreement between inertia and optical based motion capture during the VU-Return-to-Play field test. *Sensors*, 20(3), 831. <https://doi.org/10.3390/s20030831>
151. Rigoni, M., Gill, S., Babazadeh, S., Elsewaisy, O., Gillies, H., Nguyen, N., Pathirana, P. N., & Page, R. (2019). Assessment of shoulder range of motion using a wireless inertial motion capture device—A validation study. *Sensors*, 19(8), 1781. <https://doi.org/10.3390/s19081781>

152. Roberts, R., Lewis, J. P., Anjyo, K., et al. (2019). Optimal and interactive keyframe selection for motion capture. *Computational Visual Media*, 5(2), 171-191. <https://doi.org/10.1007/s41095-019-0138-z>
153. Rosca, S. D., Leba, M., & Panaite, A. F. (2020). Modelling and simulation of 3D human arm prosthesis. In Á. Rocha, H. Adeli, L. Reis, S. Costanzo, I. Orovic, & F. Moreira (Eds.), *Trends and innovations in information systems and technologies. WorldCIST 2020. Advances in intelligent systems and computing* (Vol. 1160). Springer, Cham. [https://doi.org/10.1007/978-3-030-45691-7\\_73](https://doi.org/10.1007/978-3-030-45691-7_73)
154. Rosiak, O., Pietrzak, N., Szczęsna, A., et al. (2024). The effect of immersive virtual reality on balance: An exploratory study on the feasibility of head-mounted displays for balance evaluation. *Scientific Reports*, 14, 3481. <https://doi.org/10.1038/s41598-024-54274-8>
155. Safonova, A., Hodgins, J. K., & Pollard, N. S. (2004). Synthesizing physically realistic human motion in low-dimensional, behavior-specific spaces. *ACM Transactions on Graphics*, 23(3), 514-521. <https://doi.org/10.1145/1015706.1015754>
156. Saucier, D., Davarzani, S., Turner, A., Luczak, T., Nguyen, P., Carroll, W., Burch V, R. F., Ball, J. E., Smith, B. K., Chander, H., et al. (2019). Closing the wearable gap—Part IV: 3D motion capture cameras versus soft robotic sensors comparison of gait movement assessment. *Electronics*, 8(12), 1382. <https://doi.org/10.3390/electronics8121382>
157. Scott, B., Seyres, M., Philp, F., Chadwick, E. K., & Blana, D. (2022). Healthcare applications of single camera markerless motion capture: A scoping review. *PeerJ*, 10, e13517. <https://doi.org/10.7717/peerj.13517>
158. Secco, E. L., Maereg, A. T., Reid, D., & Nagar, A. K. (2018). An integrated haptic system combining VR, a markerless motion capture system, and tactile actuators. *EAI Endorsed Transactions on Ambient Systems*, 5(17). <https://doi.org/10.4108/eai.23-3-2018.154375>
159. Sekiguchi, Y., Kokubun, T., Hanawa, H., Shono, H., Tsuruta, A., & Kanemura, N. (2020). Evaluation of the validity, reliability, and kinematic characteristics of multi-segment foot models in motion capture. *Sensors*, 20(16), 4415. <https://doi.org/10.3390/s20164415>
160. Sellers, W. I., & Hirasaki, E. (2014). Markerless 3D motion capture for animal locomotion studies. *Biology Open*, 3(7), 656-668. <https://doi.org/10.1242/bio.20148086>
161. Shakir, D. I., García-Peraza-Herrera, L. C., Daga, P., Doel, T., Clarkson, M. J., Ourselin, S., & Vercauteren, T. (2017). GIFT-Grab: Real-time C++ and Python multi-channel video capture, processing and encoding API. *Journal of Open Research Software*, 5(1), 27. <https://doi.org/10.5334/jors.169>
162. Shimada, S., Golyanik, V., Li, Z., Pérez, P., Xu, W., & Theobalt, C. (2022). HULC: 3D human motion capture with pose manifold sampling and dense contact guidance. In S. Avidan, G. Brostow, M. Cissé, G. M. Farinella, & T. Hassner (Eds.), *Computer Vision - ECCV 2022. Lecture Notes in Computer Science* (Vol. 13682). Springer, Cham. [https://doi.org/10.1007/978-3-031-20047-2\\_30](https://doi.org/10.1007/978-3-031-20047-2_30)
163. Shotton, J., et al. (2011). Real-time human pose recognition in parts from single depth images. In *CVPR 2011* (pp. 1297-1304). IEEE. <https://doi.org/10.1109/CVPR.2011.5995316>
164. Sila-Nowicka, K., & Thakuriah, P. (2019). Multi-sensor movement analysis for transport safety and health applications. *PLOS ONE*, 14(1), e0210090. <https://doi.org/10.1371/journal.pone.0210090>
165. Skublewska-Paszkowska, M., Montusiewicz, J., Łukasik, E., Pszczoła-Pasierbiewicz, I., Baran, K. R., Smółka, J., & Pueo, B. (2016). Motion capture as a modern technology for analysing ergometer rowing. *Advances in Science and Technology Research Journal*, 10(29), 132-140. <https://doi.org/10.12913/22998624/61941>
166. Skurowski, P., & Pawlyta, M. (2019). On the noise complexity in an optical motion capture facility. *Sensors*, 19, 4435. <https://doi.org/10.3390/s19204435>
167. Slipsager, J. M., Ellegaard, A. H., Glimberg, S. L., Paulsen, R. R., Tisdall, M. D., Wighton, P., et al. (2019). Markerless motion tracking and correction for PET, MRI, and simultaneous PET/MRI. *PLoS ONE*, 14(4), e0215524. <https://doi.org/10.1371/journal.pone.0215524>

168. Snoswell, A. J., Yamada, M., Kirby, G. T. S., Singh, S. P. N., & Prow, T. W. (2020). Motion capture quantification of user variation in topical microparticle application. *Frontiers in Pharmacology*, 11, 1343. <https://doi.org/10.3389/fphar.2020.01343>
169. Sun, C., Sun, P., & Wang, P. (2015). An improvement of pose measurement method using global control points calibration. *PLoS ONE*, 10(7), e0133905. <https://doi.org/10.1371/journal.pone.0133905>
170. Suzuki, Y., Inoue, T., & Nomura, T. (2018). A simple algorithm for assimilating marker-based motion capture data during periodic human movement into models of multi-rigid-body systems. *Frontiers in Bioengineering and Biotechnology*, 6, 141. <https://doi.org/10.3389/fbioe.2018.00141>
171. Szczesna, A., Skurowski, P., Lach, E., Pruszowski, P., Pęszor, D., Paszkuta, M., Słupik, J., Lebek, K., Janiak, M., Polański, A., et al. (2017). Inertial motion capture costume design study. *Sensors*, 17(3), 612. <https://doi.org/10.3390/s17030612>
172. Szczesna, A., Błaszczyszyn, M., & Pawlyta, M. (2021). Optical motion capture dataset of selected techniques in beginner and advanced Kyokushin karate athletes. *Scientific Data*, 8, 13. <https://doi.org/10.1038/s41597-021-00801-5>
173. Teramoto, K., Mukainakano, R., Watanabe, H., Hashizume, H., & Sugimoto, M. (2019). 3D tracking using smartphones for a marker-based optical motion capture system. *International Conference on Indoor Positioning and Indoor Navigation*. Available at <https://ceur-ws.org/Vol-2498/short10.pdf>
174. Teranishi, N. (2016). Analysis of subthreshold current reset noise in image sensors. *Sensors*, 16(5), 663. <https://doi.org/10.3390/s16050663>
175. Texas Instruments. (2010-2019). STEM activities with TI-Nspire. Retrieved from <https://www.stem.org.uk/rxt82>
176. Tien, R. N., Tekriwal, A., Calame, D. J., Platt, J. P., Baker, S., Seeberger, L. C., Kern, D. S., Person, A. L., Ojemann, S. G., Thompson, J. A., & Kramer, D. R. (2022). Deep learning based markerless motion tracking as a clinical tool for movement disorders: Utility, feasibility and early experience. *Frontiers in Signal Processing*, 2. <https://doi.org/10.3389/frsip.2022.884384>
177. Tits, M., Tilmanne, J., & Dutoit, T. (2018). Robust and automatic motion-capture data recovery using soft skeleton constraints and model averaging. *PLoS ONE*, 13(7), e0199744. <https://doi.org/10.1371/journal.pone.0199744>
178. Torresani, L., Hertzmann, A., & Bregler, C. (2008). Nonrigid structure-from-motion: Estimating shape and motion with hierarchical priors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(5), 878-892. <https://doi.org/10.1109/TPAMI.2007.70752>
179. Tsilomitrou, O., Gkoutas, K., Evangelidou, N., & Dermatas, E. (2021). Wireless motion capture system for upper limb rehabilitation. *Applied System Innovation*, 4(1), 14. <https://doi.org/10.3390/asi4010014>
180. Usami, T., Nishida, K., Iguchi, H., Okumura, T., Sakai, H., Ida, R., Horiba, M., Kashima, S., Sahashi, K., Asai, H., Nagaya, Y., Murakami, H., Ueki, Y., & Kuroyanagi, G. (2022). Evaluation of lower extremity gait analysis using Kinect V2® tracking system. *SICOT-J*, 8, 27. <https://doi.org/10.1051/sicotj/2022027>
181. Wang, P., Wang, J., Wei, X., Meng, J., & Xun, J. (2020). Motion recurring pattern analysis: A lossless representation for motion capture databases. *IEEE Access*, 8, 78932-78941. <https://doi.org/10.1109/ACCESS.2020.2989430>
182. Wang, J.-p., Wang, S.-h., Wang, Y.-q., Hu, H., Yu, J.-w., Zhao, X., Liu, J.-l., Chen, X., & Li, Y. (2021). A data process of human knee joint kinematics obtained by motion-capture measurement. *BMC Medical Informatics and Decision Making*, 21(1), 121. <https://doi.org/10.1186/s12911-021-01483-0>
183. Wang, Q., Kurillo, G., Ofli, F., & Bajcsy, R. (2015). Evaluation of pose tracking accuracy in the first and second generations of Microsoft Kinect. [Unpublished manuscript]. <https://doi.org/10.13140/RG.2.1.4789.0009>

184. Welch, G., & Foxlin, E. (2002). Motion tracking: No silver bullet, but a respectable arsenal. *IEEE Computer Graphics and Applications*, 22(6), 24-38. <https://doi.org/10.1109/MCG.2002.1046626>
185. Westlund, J. K., D'Mello, S. K., & Olney, A. M. (2015). Motion Tracker: Camera-based monitoring of bodily movements using motion silhouettes. *PLoS ONE*, 10(6), e0130293. <https://doi.org/10.1371/journal.pone.0130293>
186. Wu, B., Zhu, Y., Nishimura, S., & Jin, Q. (2020). Analyzing the effects of driving experience on prebraking behaviors based on data collected by motion capture devices. *IEEE Access*, 8, 197337-197351. <https://doi.org/10.1109/ACCESS.2020.3034594>
187. Yao, S., Queathem, E., Neville, D., & Kelty-Stephen, D. (2018). Teaching movement science with full-body motion capture in an undergraduate liberal arts psychology class. *Research in Learning Technology*, 26. <https://doi.org/10.25304/rlt.v26.2119>
188. Yin, K., Loken, K., & van de Panne, M. (2007). SIMBICON: Simple biped locomotion control. *ACM SIGGRAPH 2007 Papers*. <https://www.cs.ubc.ca/~van/papers/2007-siggraph-simbicon.pdf>
189. Yun, Q., & Leng, C. (2020). Intelligent control of urban lighting system based on video image processing technology. *IEEE Access*, 8, 155506-155518. <https://doi.org/10.1109/ACCESS.2020.3019284>
190. Yükseltürk, E., Erbay, H., & Kutlu, M. (2017). Motion capture technology in sports science: 3D virtual sports platform with Kinect. *Turkish Journal of Sports Medicine*, 52(4), 155-162. <https://doi.org/10.5152/tjism.2017.083>
191. Zakhem, E., Murphy, S. V., Davis, M. L., Raghavan, S., & Lam, M. T. (2016). Image and video acquisition and processing for clinical application. *Biomedical Engineering and Computational Biology*, 7(s1). <https://doi.org/10.4137/BECB.S40272>
192. Zatsiorsky, V. M. (1998). Kinematics of human motion. *Human Kinetics*. Available at <https://archive.org/details/kinematicsofhuma0000zats>
193. Zhang, Q., Zhang, S., & Zhou, D. (2014). Keyframe extraction from human motion capture data based on a multiple population genetic algorithm. *Symmetry*, 6(4), 926-937. <https://doi.org/10.3390/sym6040926>
194. Zhu, Z., Li, X., Wang, Z., He, L., He, B., & Xia, S. (2020). Development and research of a multi-medium motion capture system for underwater intelligent agents. *Applied Sciences*, 10(18), 6237. <https://doi.org/10.3390/app10186237>
195. Zhu, L., Feng, M., Yin, X., Wang, S., & Yu, J. (2017). Kinematics analysis of cervical rotation-traction manipulation measured by a motion capture system. *Evidence-Based Complementary and Alternative Medicine*, 2017, 1-6. <https://doi.org/10.1155/2017/5293916>